

直線回帰とロジスティック回帰の違い

図1のように、従属変数が2値変数（2種類の値のどちらかしかとらない）場合に、直線回帰を行うのは不適切である。例えば、0/1 データの場合、[0, 1] の値をとるとすることは、1 の事象が起きる確率として解釈できるが、0未満の値や1を超える値の解釈ができない。

ある事象が発生する（従属変数が1になる）確率を P としたとき、 $\frac{P}{1-P}$ はオッズ^{*1}、その対数をとった $\log\left(\frac{P}{1-P}\right)$ はロジットまたは対数オッズと呼ばれる。

(1) 式のようにロジットが独立変数の線形結合式 $\lambda = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_p x_p$ で表せるとするのがロジスティックモデルである。 λ を線形予測子 linear predictor という。

$$\log\left(\frac{P}{1-P}\right) = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_p x_p = \lambda \quad (1)$$

^{*1} オッズというのはギャンブルで「見込み」を表すために使われるものである。成功の回数で計算されるもので、日本の公営競馬、競輪などにおけるオッズとは定義が違う。分子と分母をそれぞれ「成功の回数と失敗の回数の合計」で割れば、成功の確率 = $\frac{\text{成功の回数}}{\text{成功の回数} + \text{失敗の回数}}$ となる。成功とは「注目している事象が起きること」とする。




図1 ロジスティック回帰分析と重回帰分析の違い

(1) 式の両辺の逆対数をとった (2) は、従属変数が1になる確率と0になる確率の比をとったもの（オッズ）である。

$$\frac{P}{1-P} = \exp(b_0 + b_1 x_1 + b_2 x_2 + \dots + b_p x_p) \quad (2)$$

x_1 以外の独立変数が同じであるという条件下で、 $x_1 = u + 1$ のときのオッズと $x_1 = u$ のときのオッズの比をとると (3) 式のようになる。これは、オッズ比と呼ばれ、 x_1 が1単位増えたときに、オッズは $\exp(b_1)$ 倍になることを意味する。

$$\frac{P_{x_1=u+1}/(1-P_{x_1=u+1})}{P_{x_1=u}/(1-P_{x_1=u})} = \frac{\exp(b_0 + b_1(u+1) + b_2 x_2 + \dots + b_p x_p)}{\exp(b_0 + b_1 u + b_2 x_2 + \dots + b_p x_p)} = \exp(b_1) \quad (3)$$

(1) 式を P について解くと (4) 式のようになる。

$$P = \frac{1}{1 + \exp(-\lambda)} \quad (4)$$

P は [0, 1] の値をとり、 λ を横軸、 P を縦軸として描かれる曲線はロジスティック曲線と呼ばれる^{*2}。

ロジスティックモデルの種類

多重ロジスティックモデル 従属変数は2値データ

多項ロジスティックモデル 従属変数は3つ以上のカテゴリを持つ名義尺度データ

順序ロジスティックモデル 従属変数は3つ以上のカテゴリを持つ順序尺度データ（カテゴリに順序関係がある）

累積ロジスティックモデル

比例オッズモデル

表3 分析結果

	x_1	x_2	x_3	y	ロジット	生起確率	判別結果
1	62.4	51.7	51.8	0	0.70992	0.67038	1
2	48.3	47.9	43.8	0	-0.93017	0.28289	0
3	61.1	37.9	48.6	0	-1.52546	0.17866	0
4	48.4	42.3	37.4	0	-2.26494	0.09407	0
5	48.0	57.1	61.1	1	1.85195	0.86436	1
6	50.0	53.2	43.9	1	-0.13522	0.46625	0
7	48.0	36.0	34.9	0	-3.37063	0.03223	0
8	51.8	53.0	68.9	1	2.07540	0.88849	1
9	36.5	32.4	35.2	0	-4.18118	0.01505	0
10	33.1	47.5	43.8	0	-1.43058	0.19301	0
:	:	:	:	:	:	:	:
99	55.9	55.7	61.5	1	1.92358	0.87254	1
100	68.7	64.8	59.0	1	3.34408	0.96591	1

多重ロジスティックモデル

多重ロジスティックモデルは、従属変数が二値データである場合に適用される。分析例は表1のようなデータである。

表1 従属変数が二値データ

	x_1	x_2	x_3	y
1	62.4	51.7	51.8	0
2	48.3	47.9	43.8	0
3	61.1	37.9	48.6	0
4	48.4	42.3	37.4	0
5	48.0	57.1	61.1	1
6	50.0	53.2	43.9	1
7	48.0	36.0	34.9	0
8	51.8	53.0	68.9	1
9	36.5	32.4	35.2	0
10	33.1	47.5	43.8	0
:	:	:	:	:
99	55.9	55.7	61.5	1
100	68.7	64.8	59.0	1

分析結果は表2に示す。

表2 多重ロジスティックモデルによる解析結果

	偏回帰係数	標準誤差	z値	P値
x1	0	0.03194	0.916	0.360
x2	0	0.03880	3.582	< 0.001
x3	0	0.03785	2.310	0.021
定数項	-13	2.65285	-4.836	< 0.001

ロジット λ は、元のデータを偏回帰係数により線形変換したものである。

$$\lambda = -12.82897 + 0.02926 x_1 + 0.13895 x_2 + 0.08743 x_3$$

事象の生起確率 P は、ロジットを用いて計算される (表3)。

$$P = \frac{1}{1 + \exp(-\lambda)}$$




図2 観察値とロジットと予測値（確率）

予測値（生起確率）が0.5以上の場合、事象が発生したとすれば、予測結果は表4のようにまとめられる。正判別率は81%である。

表4 多重ロジスティックモデルによる判別結果

	0	1	合計
0	43	9	52
1	10	38	48

なお、線形判別分析によれば表5のようになる。

線形判別分析による正判別率は80%である。

表5 線形判別分析による判別結果

	0	1	合計
0	45	7	52
1	13	35	48

^{*2} 同じような「S字状曲線」を表すプロビットモデル（プロビット曲線）があるが、数学的に簡単に取り扱えるロジスティックモデルのほうがよく使われる。

多項ロジスティックモデル

多項ロジスティックモデルは、従属変数が3つ以上のカテゴリを持つ名義尺度データに適用できる。従属変数は多項分布に従うと仮定される。

表6に示したようなデータを使用する。

	x_1	x_2	x_3	y
1	62.4	51.7	51.8	3
2	48.3	47.9	43.8	1
3	61.1	37.9	48.6	1
4	48.4	42.3	37.4	2
5	48.0	57.1	61.1	3
6	50.0	53.2	43.9	2
7	48.0	36.0	34.9	1
8	51.8	53.0	68.9	3
9	36.5	32.4	35.2	1
10	33.1	47.5	43.8	1
:	:	:	:	:
99	55.9	55.7	61.5	2
100	68.7	64.8	59.0	2

分析結果は表7のように、切片と偏回帰係数の推定値が2組（従属変数のカテゴリ数より1少ない）得られる。

	偏回帰係数	標準誤差	t値
(Intercept):1	10.15774	2.328	4.363
(Intercept):2	6.39061	2.007	3.184
x1:1	-0.05806	0.036	-1.628
x1:2	-0.01886	0.032	-0.594
x2:1	-0.06200	0.038	-1.616
x2:2	-0.00890	0.034	-0.263
x3:1	-0.08079	0.041	-1.965
x3:2	-0.08902	0.036	-2.478

切片と傾きから計算されるロジットは、判別される群の数より1つ少ない個数だけ計算される（表8）。ロジット1は $y=3$ のものに対する $y=1$ のロジット、ロジット2は $y=3$ のものに対する $y=2$ のロジットを意味する。

	x_1	x_2	x_3	y	logit_1	logit_2	p_1	p_2	p_3	判別結果
1	62.4	51.7	51.8	3	-0.85600	0.14297	0.16477	0.44742	0.38781	2
2	48.3	47.9	43.8	1	0.84462	1.15479	0.35799	0.48818	0.15384	2
3	61.1	37.9	48.6	1	0.33369	0.57509	0.33453	0.42586	0.23961	2
4	48.4	42.3	37.4	2	1.70313	1.77242	0.44368	0.47552	0.08080	2
5	48.0	57.1	61.1	3	-1.10616	-0.46136	0.16868	0.32144	0.50988	3
6	50.0	53.2	43.9	2	0.40921	1.06669	0.27823	0.53697	0.18480	2
7	48.0	36.0	34.9	1	2.31897	2.05855	0.53502	0.41235	0.05263	1
8	51.8	53.0	68.9	3	-1.70277	-1.19088	0.12259	0.20453	0.67289	3
9	36.5	32.4	35.2	1	3.18563	2.28073	0.69159	0.27981	0.02860	1
10	33.1	47.5	43.8	1	1.75192	1.44499	0.52379	0.38536	0.09085	1
:	:	:	:	:	:	:	:	:	:	:
99	55.9	55.7	61.5	2	-1.51034	-0.63349	0.12608	0.30301	0.57092	3
100	68.7	64.8	59.0	2	-2.61576	-0.73328	0.04706	0.30920	0.64373	3

3つのカテゴリの生起確率は、

$$\text{従属変数が} \begin{cases} 1 \text{ である確率 } p_1 = \frac{\exp(\text{logit}_1)}{1 + \exp(\text{logit}_1) + \exp(\text{logit}_2)} \\ 2 \text{ である確率 } p_2 = \frac{\exp(\text{logit}_2)}{1 + \exp(\text{logit}_1) + \exp(\text{logit}_2)} \\ 3 \text{ である確率 } p_3 = \frac{1}{1 + \exp(\text{logit}_1) + \exp(\text{logit}_2)} \end{cases} \quad (5)$$

により計算される。

従属変数を予測するには、計算された確率が最も高いものであると判別すればよい。判別結果は表9に示す。

正判別率は54%である。

表9 多項ロジスティック判別による判別結果

	1	2	3	合計
1	14	15	2	31
2	8	21	10	39
3	4	7	19	30

なお、正準判別分析による判別結果は表10のようになる。

正準判別分析による正判別率は54%である。

表10 正準判別分析による判別結果

	1	2	3	合計
1	14	15	2	31
2	8	21	10	39
3	3	8	19	30

順序ロジスティックモデル

従属変数が3つ以上のカテゴリを持ち、しかもそのカテゴリに順序関係がある場合（順序尺度データ）に使用されるモデルである。

表6のデータを用いる。ただし、従属変数には $1 < 2 < 3$ のように順序がある、順序尺度だとする。

累積ロジスティックモデル (cumulative logistic model) では、まず、「1」を「反応あり」、「2」と「3」を「反応なし」として

$$A_1 = \log \frac{\pi_1}{1 - \pi_1} = \beta_{10} + \beta_{11} x_1 + \dots + \beta_{1p} x_p + \epsilon_1 \quad (6)$$

を当てはめる。

次に「1」と「2」を「反応あり」、「3」を「反応なし」として

$$A_2 = \log \frac{\pi_2}{1 - \pi_2} = \beta_{20} + \beta_{21} x_1 + \dots + \beta_{2p} x_p + \epsilon_2 \quad (7)$$

を当てはめる。

ここで、(6)式と(7)式の偏回帰係数において、 $\beta_{10} \neq \beta_{20}$ であるがそのほかの偏回帰係数は $\beta_{1i} = \beta_{2i}$ であると考える場合と、偏回帰係数は全て異なる ($\beta_{1i} \neq \beta_{2i}$) と考える場合とがある。

前者は、2つのモデルのオッズの間には比例関係がありその比例定数は $\exp(\beta_{10} - \beta_{20})$ となるので、このような累積ロジスティックモデルは特に比例オッズモデル (proportional odds model, POM) と呼ぶ。2つのモデルのオッズの間には比例関係があり (ロジットの差 $\beta_{10} - \beta_{20}$ は一定)、その比例定数は定数項の差を指数変換した値になる。

後者では、比例関係はない。

図3のロジスティック曲線において、 (logit_1, p_1) と (logit_2, p_2) がそれぞれ(6)式と(7)式によるものとする。ロジットに対応する生起確率に基づいて、そのデータが従属変数のどのカテゴリに属するかは、以下のように予測される。

まず、赤の logit_1 に対する p_1 は「1」を「反応あり」としたものであるから、確率 p_1 は「1」である確率である。

次に、黒の logit_2 に対する p_2 は、「1」と「2」を「反応あり」としたものであるから、確率 p_2 は「1」または「2」である確率なので、 $1 - p_2$ が「3」の確率である。

よって、 $1 - \{1 - (1 - p_2) + p_1\} = p_2 - p_1$ が「2」である確率である。




図3 それぞれの確率

比例オッズモデル

表 11 比例オッズモデルの結果

	偏回帰係数	標準誤差	z 値
(Intercept):1	5.82201	1.369	4.252
(Intercept):2	7.90346	1.482	5.333
x1	-0.03717	0.023	-1.613
x2	-0.04146	0.025	-1.673
x3	-0.05854	0.026	-2.210

表 12 において、 \logit_1 と \logit_2 の差は一定である。

表 12 比例オッズモデルの結果

	x_1	x_2	x_3	y	\logit_1	\logit_2	p_1	p_2	p_3	判別結果
1	62.4	51.7	51.8	3	-1.67314	0.40831	0.15801	0.44268	0.39932	2
2	48.3	47.9	43.8	1	-0.52319	1.55826	0.37211	0.45400	0.17390	2
3	61.1	37.9	48.6	1	-0.86536	1.21609	0.29622	0.47515	0.22863	2
4	48.4	42.3	37.4	2	0.07991	2.16136	0.51997	0.37676	0.10327	1
5	48.0	57.1	61.1	3	-1.90619	0.17526	0.12941	0.41429	0.45630	3
6	50.0	53.2	43.9	2	-0.81196	1.26949	0.30747	0.47318	0.21935	2
7	48.0	36.0	34.9	1	0.50232	2.58377	0.62300	0.30681	0.07019	1
8	51.8	53.0	68.9	3	-2.33406	-0.25261	0.08834	0.34884	0.56282	3
9	36.5	32.4	35.2	1	1.06146	3.14291	0.74297	0.21566	0.04137	1
10	33.1	47.5	43.8	1	0.05838	2.13983	0.51459	0.38012	0.10529	1
...
99	55.9	55.7	61.5	2	-2.16520	-0.08375	0.10292	0.37616	0.52093	3
100	68.7	64.8	59.0	2	-2.87190	-0.79045	0.05356	0.25851	0.68793	3

正判別率は 52% である。

表 13 比例オッズモデル判別による判別結果

	1	2	3	合計
1	14	15	2	31
2	9	22	8	39
3	2	12	16	30

累積ロジスティックモデル

表 14 累積ロジスティックモデルの結果

	偏回帰係数	標準誤差	z 値
(Intercept):1	5.47001	1.674	3.267
(Intercept):2	8.39935	1.858	4.521
x1:1	-0.04906	0.028	-1.757
x1:2	-0.03050	0.029	-1.054
x2:1	-0.06385	0.031	-2.088
x2:2	-0.02197	0.031	-0.709
x3:1	-0.01619	0.032	-0.503
x3:2	-0.09341	0.033	-2.859

表 15 において、 \logit_1 と \logit_2 の差は一定ではない。

表 15 累積ロジスティックモデルの結果

	x_1	x_2	x_3	y	\logit_1	\logit_2	p_1	p_2	p_3	判別結果
1	62.4	51.7	51.8	3	-1.73110	0.52173	0.15045	0.47711	0.37245	2
2	48.3	47.9	43.8	1	-0.66717	1.78256	0.33913	0.51688	0.14399	2
3	61.1	37.9	48.6	1	-0.73442	1.16342	0.32423	0.43773	0.23805	2
4	48.4	42.3	37.4	2	-0.21090	2.50036	0.44747	0.47670	0.07583	2
5	48.0	57.1	61.1	3	-1.51999	-0.02643	0.17946	0.31393	0.50661	3
6	50.0	53.2	43.9	2	-1.09058	1.60495	0.25151	0.58120	0.16729	2
7	48.0	36.0	34.9	1	0.25144	2.88447	0.56253	0.38454	0.05293	1
8	51.8	53.0	68.9	3	-1.57096	-0.78090	0.17208	0.14205	0.68587	3
9	36.5	32.4	35.2	1	1.04064	3.28627	0.73897	0.22498	0.03605	1
10	33.1	47.5	43.8	1	0.10410	2.25494	0.52600	0.37907	0.09492	1
...
99	55.9	55.7	61.5	2	-1.82467	-0.27399	0.13888	0.29305	0.56807	3
100	68.7	64.8	59.0	2	-2.99317	-0.63074	0.04774	0.29961	0.65266	3

正判別率は 52% である。

表 16 累積ロジスティックモデル判別による判別結果

	1	2	3	合計
1	13	16	2	31
2	8	21	10	39
3	3	9	18	30